

Detecção Automática de *Fake News*: Revisão Sistemática

Alice Barbosa, Felipe Sousa, Reinaldo Braga

¹Laboratório de Redes de Computadores e Sistemas (LAR)
Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

Abstract. *The adherence to social networks has allowed easy access to information with one click, offering mechanisms with a wide reach of dissemination in the Internet. However, the large volume of sharing, as well as the challenge of validating the veracity of the data, promotes a favorable environment for the proliferation of fake news. With the rise of Fake News, several studies have been carried out to identify fake news using Natural Language Processing. This article presents a systematic review of Brazilian and international studies on the detection of fake news. The results show that Twitter is the social network most studied by the articles and Support Vector Machine and Naive Bayes are the most applied classification algorithms.*

Resumo. *A adesão às redes sociais tem permitido o fácil acesso à informações com um clique, oferecendo mecanismos com amplo alcance de divulgação. Porém, o grande volume de compartilhamento, bem como o desafio de validar a veracidade dos dados, promove um ambiente favorável para a proliferação de notícias falsas. Com o aumento das fake news, estudos têm sido realizados para identificar notícias falsas usando Processamento de Linguagem Natural. Este artigo apresenta uma revisão sistemática de estudos brasileiros e internacionais sobre a detecção de notícias falsas. Os resultados mostram que o Twitter é a rede social mais estudada pelos artigos e o Support Vector Machine e Naive Bayes são os algoritmos de classificação mais aplicados.*

1. Introdução

O avanço da tecnologia tem trazido novas práticas na vida social, proporcionando meios modernos de comunicação e oferecendo facilidade e celeridade na realização de tarefas cotidianas. Esta realidade representa um fator importante para o aumento do número de usuários ativos que acessam a Internet no mundo. Segundo uma pesquisa publicada pela [DataReportal 2023], atualmente, existem 5,16 bilhões de usuários de Internet no mundo, o que significa que 64,4% da população total do mundo está *online*.

O estudo da [DataReportal 2023] revela que cerca de 4,76 bilhões de usuários estão conectados às mídias sociais. Ao mesmo tempo que o avanço das redes sociais tem sido importante para a sociedade, elas também têm impulsionado o consumo de notícias *online*. Em uma pesquisa realizada pelo *Institute Reuters* [Reuters and of Oxford 2021] em 12 países, cerca de 66% dos entrevistados declararam usar duas ou mais redes sociais para compartilhar ou discutir notícias. Entre as mais citadas estão WhatsApp, Instagram, TikTok, Telegram e Facebook.

Porém, a facilidade de acesso, a velocidade com que as informações são compartilhadas, aliadas ao baixo custo, também proporcionam um espaço propício para

a proliferação de notícias falsas (*fake news*), que podem ser definidas como artigos de notícias com conteúdos intencional e comprovadamente falsos, sendo capazes de enganar os leitores, muitas vezes para a obtenção de vantagens financeiras ou por motivações ideológicas, como o favorecimento de candidatos a cargos políticos [Allcott and Gentzkow 2017]. A difusão e a acessibilidade da Internet facilitam o acesso às informações para as grandes massas em um clique [Kumar et al. 2021]. Porém, essa acessibilidade à rede não oferece aos usuários as mesmas facilidades para a verificação da veracidade das informações.

Devido ao risco que a propagação de *fake news* representa à democracia, muitos esforços têm sido empenhados no sentido de desenvolver estratégias para a identificação de notícias falsas e, assim, minimizar os seus danos à sociedade [Sharma et al. 2019]. Dentre as estratégias adotadas, a mais convencional é a checagem de fatos, que consiste na análise humana para verificação de alegações contra evidências baseadas em fatos previamente falados ou escritos. No entanto, à medida que o número de usuários da Internet e a velocidade da disseminação de informações estão crescendo, a automatização do processo de detecção de notícias falsas tem despertado cada vez mais interesse tanto na comunidade acadêmica, quanto nos governos e na sociedade [Oshikawa et al. 2020]. Neste sentido, muitos estudos que buscam solucionar este problema fazem uso das técnicas de Processamento de Linguagem Natural (PLN) combinadas a algoritmos de Aprendizado de Máquina (AM) [Medeiros and Braga 2020].

Este artigo apresenta uma Revisão Sistemática (RS) no contexto da detecção automática de notícias falsas. A metodologia adotada foi dividida em três etapas principais. Na primeira etapa (Planejamento), foram definidas as Questões de Pesquisa (QP), os protocolos de busca, os critérios de inclusão e exclusão, e os critérios de qualidade. Na segunda etapa (Condução), foi realizada a triagem dos artigos selecionados mediante os critérios da etapa anterior. Por fim, a última etapa (Resultados) responde de forma visual e descritiva as QP, e apresenta discussões a cerca das QP levantadas. Dado o grande volume de dados, a ferramenta de *Business Intelligence* Tableau foi utilizada para análise visual. Os resultados alcançados podem ser usados como referência por pesquisadores e profissionais interessados na área, assim como podem ser utilizados como subsídio para otimizar a tomada de decisão de analistas de dados quanto ao uso de ferramentas, algoritmos e bases de dados em projetos na área.

2. Metodologia

A metodologia está dividida em três etapas principais, apresentadas a seguir. Todas as etapas foram realizadas com o auxílio do programa *Parsifal*.

2.1. Etapa 1: Planejamento

O planejamento compreende a realização da revisão bibliográfica, possibilitando uma familiarização com a temática a ser estudada e auxiliando no preenchimento dos protocolos de busca [Cerrao et al. 2018]. As atividades de planejamento são: (I) Definir as Questões de Pesquisa (QP) da revisão; (II) Produzir um protocolo de busca; (III) Estabelecer os critérios de qualidade e (IV) Determinar os critérios de inclusão e exclusão.

2.1.1. Questões de Pesquisa (QP)

As questões que norteiam a presente RS são: Q1: Como estão distribuídos os trabalhos de detecção automática de *fake news* ao longo dos anos? Q2: Quais os tipos de publicações

científicas mais recorrentes no contexto das *fake news*? Q3: Quais países têm mais pesquisadores publicando sobre detecção de *fake news*? Q4: Quais tipos de conteúdo estão sendo considerados como solução na detecção de *fake news*? Q5: Quais as redes sociais mais utilizadas no desenvolvimento dos trabalhos? Q6: Quais os *datasets* mencionados nos trabalhos selecionados? Q7: Quais algoritmos de inteligência artificial são aplicados nas pesquisas? Q8: Quais estudos apresentam resultados mais qualificados quanto às métricas de avaliação?

2.1.2. Protocolos de busca

Para os protocolos de busca foi aplicada uma tabela PICO (População, Intervenção, Comparação e Resultados). O protocolo de busca foi definido conectando os termos presentes na Tabela 1, usando os termos lógicos “AND” e “OR”.

Tabela 1. Tabela PICO.

Elemento	Descrição	Keywords
População	Meios sociais de propagação de fake news.	Social media e Social networks
Intervenção	Detecção de fake news, desinformação, boatos e rumores	Fake news, Rumor e Misinformation
Comparação	Comparar desempenho dos algoritmos de IA	Machine learning e Deep learning
Outcomes	Validação dos resultados alcançados	-

A busca foi executada em cinco portais científicos: *ACM Digital Library*, *IEEEExplore*, *ScienceDirect*, *SpringerLink* e *SBC OpenLib*. A Tabela 2 apresenta os protocolos de busca utilizados em cada portal, já que cada um tem *layout* e sintaxe de busca diferente.

Tabela 2. Sintaxe de busca.

Portais científicos	Protocolos de busca
<i>ACM Digital Library</i>	"query": {Fulltext:(social media OR social networks) AND Fulltext:(Fake News OR rumour OR misinformation) AND Fulltext:(machine learning OR deep learning)}
<i>IEEEExplore</i>	("Full Text & Metadata":social media) OR ("Full Text & Metadata":social networks) AND ("Full Text & Metadata":Fake News) OR ("Full Text & Metadata":rumour) OR ("Full Text & Metadata":misinformation) AND ("Full Text & Metadata":machine learning) OR ("All Metadata":deep learning)
<i>ScienceDirect</i>	all:{(social media OR social networks) AND (Fake News OR rumour OR misinformation) AND (machine learning OR deep learning)}
<i>SpringerLink</i>	detection AND learning AND social AND "Fake News"AND (machine OR deep OR media OR network OR news) filters: computer science And article
<i>SBC OpenLib</i>	Busca manual

2.1.3. Critérios de Qualidade

Os critérios de qualidade têm como propósito fornecer critérios de inclusão/exclusão mais detalhados, além de investigar se as variações de qualidade fornecem uma explicação para as diferenças nos resultados do estudo [Keele et al. 2007]. As avaliações de qualidade geralmente são baseadas em uma lista de verificação de fatores que precisam ser ponderados para cada estudo. Os itens estabelecidos no processo de avaliação recebem uma “nota”, que influencia na inclusão ou exclusão do estudo.

Para a seleção dos trabalhos, 10 critérios de qualidade foram estabelecidos. Para cada critério, há três possíveis respostas, sendo elas: **Presente (peso=10)**; **Parcialmente (peso=5)**; **Ausente (peso=0)**. Desta forma, o artigo que atingir nota maior ou igual 7 é classificado como aprovado. Os critérios são: C1: A motivação e a justificativa ficaram claras ao longo do trabalho? C2: Os objetivos foram estabelecidos de forma coesa? C3: A pesquisa foi bem fundamentada teoricamente? C4: O trabalho expõe de forma

transparente e objetiva a metodologia desenvolvida, sendo sempre justificadas as decisões tomadas? C5: A solução proposta foi detalhada completamente? C6: A base de dados utilizada no trabalho foi apresentada de forma adequada? A sua escolha foi justificada? C7: Os resultados apresentados foram claramente relatados? C8: As figuras e tabelas estão legíveis? As mesmas foram devidamente relatadas ao longo do trabalho? C9: Os resultados são consistentes com os objetivos apresentados? C10: De forma geral, o pesquisador conseguiu apresentar um trabalho claro e objetivo?

2.1.4. Critérios de Inclusão e Exclusão

Os critérios de **inclusão** foram: (i) Trabalhos que apresentem um modelo com resultados; (ii) Apresentam métricas de avaliação como acurácia, F1, precisão e/ou revocação;

Os critérios de **exclusão** foram: (i) Trabalhos não escritos em inglês ou português; (ii) Trabalhos publicados antes de 2016; (iii) Trabalhos em andamento; (iv) Trabalhos duplicados; (v) Estudos muito específicos, como por exemplo: detecção com imagens ou apenas focado no perfil dos autores de *fake news*; (vi) Trabalhos de cunho teórico como, *Surveys* e revisões sistemáticas ou literárias; (vii) Trabalhos que não apresentem em seu texto referência à base de dados utilizada na pesquisa; (viii) Trabalhos que apresentem *dataset* com menos de 1.000 notícias verdadeiras e falsas; (ix) Trabalhos que não atingiram a pontuação estabelecida nos critérios de qualidade.

2.2. Etapa 2: Condução

Ao fim da etapa de planejamento, é iniciado o processo de condução. Ao todo foram reunidos 4.908 estudos. Vale ressaltar que os trabalhos foram coletados dentro do período de 7 anos, iniciando em 2016, até novembro de 2022 (período de desenvolvimento do presente estudo). De posse dos trabalhos, o processo de avaliação para adesão ou eliminação é instaurado. Para isto, são utilizadas as recomendações PRISMA, que consistem em: Identificação, Seleção, Elegibilidade e Inclusão.

Na **identificação**, pontos estratégicos foram avaliados com o objetivo de acelerar a aferição dos artigos. Foram analisados os títulos, *abstracts* e *keywords*, além de verificar artigos duplicados. Este processo resultou na eliminação de 4.705 artigos. Neste ponto, com 203 artigos, é realizada a **seleção** dos trabalhos. O processo consiste na aplicação dos 10 critérios de qualidade estabelecidos na Seção 2.1.3 e avaliação mediante às notas obtidas, o que resultou na eliminação de 110 trabalhos.

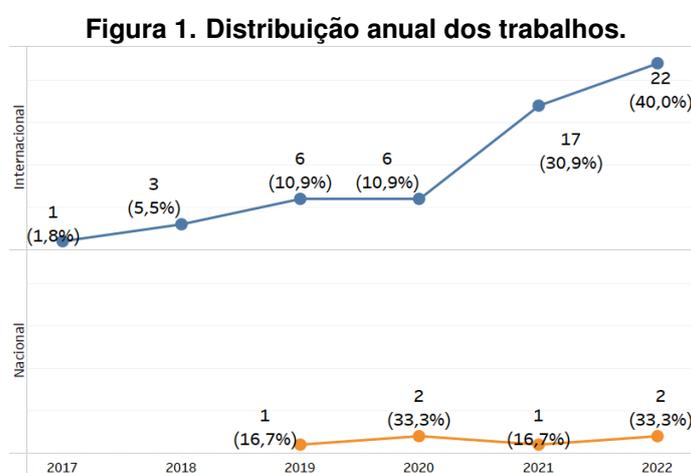
Com 93 estudos resultantes do processo de seleção, é iniciada a análise quanto à **elegibilidade**. Nesse ponto são avaliadas a replicabilidade dos estudos e a qualidade dos resultados, não apenas acurácia, mas também precisão, matriz de confusão entre outras métricas de avaliação. Desta forma, 32 estudos foram eliminados. Por fim, 61 trabalhos foram **incluídos** para a continuação da presente revisão.

3. Resultados

Os resultados foram obtidos a partir da análise dos 61 artigos da RS, respondendo as QP da Seção 2.1.1. As análises são dispostas em dois cenários: Nacional (pesquisas com *dataset* em Língua Portuguesa) e Internacional (com *dataset* em idioma diferente do português).

3.1. Como estão distribuídos os trabalhos de detecção automática de fake news ao longo dos anos?

Na Figura 1 é apresentada a distribuição anual das pesquisas selecionadas no contexto de detecção automática de *fake news* em nível nacional e internacional. É possível observar que o número de estudos era escasso em 2017. Destaca-se ainda que, nacionalmente, não há registros neste ano. Entre 2018 a 2022, é apresentado um aumento no número de estudos, sendo 2022 o ano com maior número de pesquisas, tanto internacionalmente, quanto nacionalmente, com 22 (40%) e 2 (33,33%) estudos, respectivamente. É importante destacar que este aumento no volume de estudos durante o ano de 2021 e 2022 pode ser atribuído à preocupação em torno da disseminação de *fake news* relacionadas à pandemia causada pelo COVID-19.



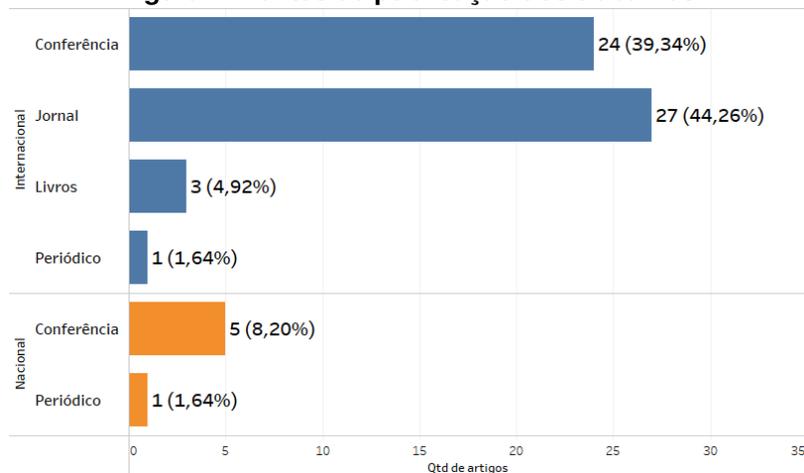
3.2. Quais os tipos de publicações científicas mais recorrentes no contexto das fake news?

A Figura 2 exibe os tipos de publicações científicas mais recorrentes no contexto das notícias falsas. Como pode ser observado, no cenário internacional 27 (44,26%) dos artigos selecionados são publicados em jornais, já no cenário nacional o maior número de artigos é em conferências, no caso, 5 (8,20%) trabalhos. Todavia, no cenário internacional a diferença para o número de trabalhos publicados em conferências não é muito grande, apresentando 24 (39,34%) artigos. Destaca-se que, o volume de trabalhos publicados em conferências pode ser atribuído ao processo de avaliação, como também ao escopo e as discussões técnicas.

3.3. Quais países têm mais pesquisadores publicando sobre detecção de fake news?

Mais de 50% dos autores dos estudos selecionados têm sua origem no continente asiático, 35 (57,4%), sendo a Índia o país com mais artigos, 20 (32,8%), seguido da China com 6 (9,8%). Destaca-se que, o continente americano é o segundo a apresentar um maior número de pesquisadores publicando no contexto de detecção de *fake news* com 13 (21,3%) estudos, sendo os Estados Unidos da América (EUA) o país com maior registro com 7 (11,5%) artigos, ficando atrás apenas da Índia. Logo após os EUA temos o Brasil com 6 (9,8%) pesquisas. Vale ressaltar que, 80% dos trabalhos selecionados efetuam suas pesquisas apenas em Língua Inglesa ou mesclam com outro idioma. Nesta RS foi encontrado

Figura 2. Fontes de publicação dos trabalhos.



apenas um artigo, que foi a pesquisa publicada por Martín [Martín et al. 2022], no qual apresenta um modelo multilíngue para detecção de *fake news* em inglês e espanhol. Fora as duas situações, o outro idioma com maior registro de pesquisa é a Língua Portuguesa com apenas 6 (9,84%) estudos.

3.4. Quais tipos de conteúdo estão sendo considerados como solução na detecção de Fake News?

Tendo em vista os diferentes conteúdos que vêm sendo utilizados no processo de detecção de *fake news*, o presente estudo buscou averiguar quais atualmente estão sendo amplamente aplicados. Na Figura 3, é possível ter uma visão das combinações de conteúdos considerados nos estudos. No caso, o *Texto* é o principal fator para identificar uma notícia falsa, tanto no cenário nacional como internacional, com 4 (6,56%) e 34 estudos, respectivamente. Em contrapartida, a maioria dos estudos também mostram que considerando aspectos sociais é possível atingir bons resultados de detecção. Sendo que, cerca de 37% dos estudos vêm realizando análise do conteúdo dos textos quanto ao *Contexto* e/ou *Sentimento*. Internacionalmente, essa pesquisa se faz mais presente, como a análise de *Texto + Contexto* em 10 (18,18%) estudos e *Texto + Sentimento* em 9 (9,09%) estudos. No cenário nacional, o estudo dos conteúdos apresenta poucos registros, com 1 (1,64%) estudo voltado para análise de *Texto + Sentimento* e 1 (1,64%) para *Texto + Sintaxe*.

3.5. Quais as redes sociais mais utilizadas no desenvolvimento dos trabalhos?

Como mostra a Figura 4, 27 (44,26%) direcionaram suas análises a detecção em redes sociais, sendo o *Twitter* a rede mais escolhida, com 25 (40,98%). Destaca-se que esse resultado já era esperado, tendo em vista que a plataforma é um ambiente que confortável para promover opiniões e notícias, sejam elas verdadeiras ou falsas. Dentre os 25 estudos, 20 (36,36%) trabalham somente com o *Twitter*, 3 (5,45%) combinam o *Twitter* com o *Facebook* e 2 (3,64%) combinam o *Twitter* com o *Weibo*. Em contrapartida, 34 (55,74%) estudos vêm centralizando sua atenção para notícias publicadas em páginas jornalísticas. Nos estudos publicados nacionalmente, a predominância são em dados coletados da web, ou seja, de sites jornalísticos e revistas. Nos estudos publicados internacionalmente, 28 (50,91%) aderem também às notícias publicadas na web, como também de redes sociais como o *Twitter*, com 20 (36,36%).

Figura 3. Conteúdos estudados.

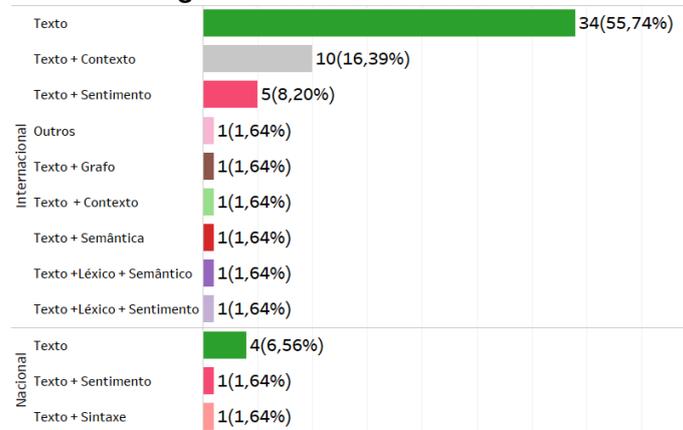
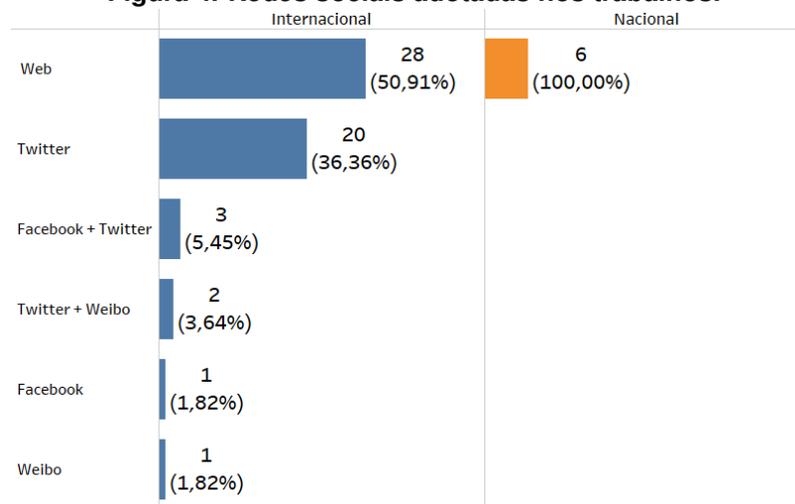


Figura 4. Redes sociais adotadas nos trabalhos.



3.6. Quais os datasets mencionados nos trabalhos selecionados?

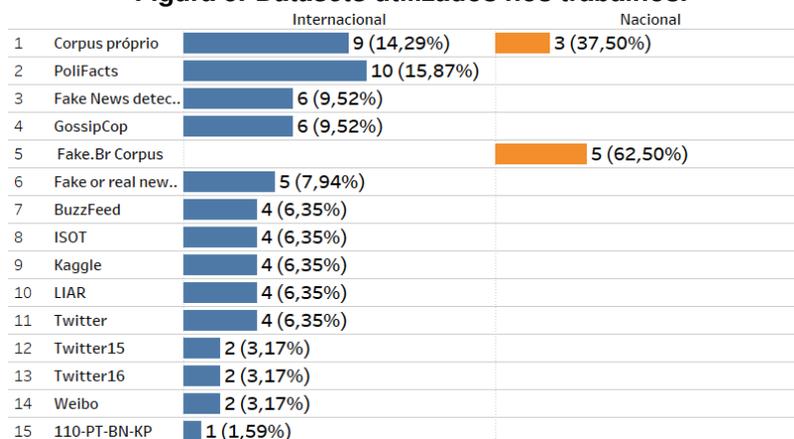
Na Figura 5, é possível visualizar os *datasets* adotados pelos artigos selecionados, ao todo foram identificados 43 *datasets*. Vale destacar que 12 (12%) dos estudos selecionados criaram seus próprios *datasets*. Frisa-se ainda que a construção do próprio *corpus* se dá tanto por meio de aplicações disponíveis pelas redes sociais, como também por meio de robôs de rastreamento, no caso, *web crawler*.

Mesmo a maior parte dos estudos criando seus próprios *corpus*, ainda há muitos estudos que optam por fazer uso de *datasets* já publicados, como as bases do *Kaggle* e *PolitiFact*. É importante frisar que, após a criação do próprio *dataset*, o *PolitiFact* é a base mais adotada, com 10 (10%) estudos. Entretanto, em uma análise por cenários, é visível que nacionalmente há apenas duas bases de dados, sendo elas: a criação de uma própria com 3 (38%) estudo e a *Fake.br Corpus*, com 5 (63%) estudos. Destaca-se que muitos estudos fizeram uso de duas bases de dados, na qual uma é aplicada apenas para o treinamento e a outra para os testes, como no trabalho publicado por Almeida [de Almeida et al. 2021].

Internacionalmente, a predominância é a base da *PolitiFact* com 10 (11%) regis-

tros e a criação de uma base própria com 9 (10%) estudos. Porém, diferente do cenário nacional, outras bases são adotadas, como a *Fake News detection - Kaggle* com 6 (7%) estudos.

Figura 5. Datasets utilizados nos trabalhos.



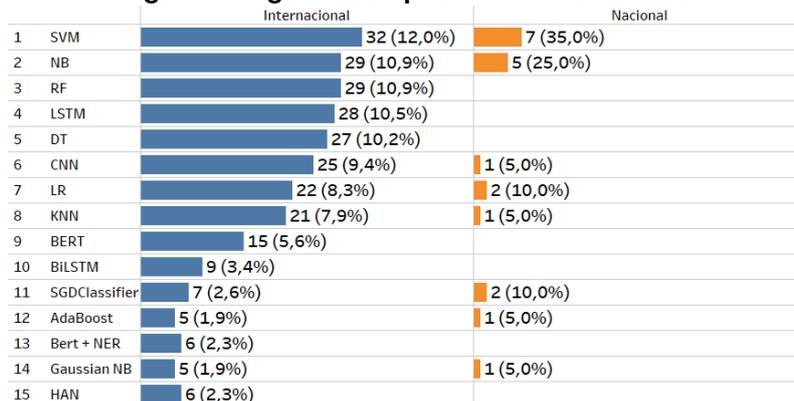
3.7. Quais algoritmos de inteligência artificial são aplicados nas pesquisas?

Na Figura 6 são listados os algoritmos que foram adotados pelos artigos selecionados. Ao todo foram identificados 80 algoritmos, sendo que nestes estão incluídas combinações entre dois e/ou três algoritmos. É importante ressaltar que em diversos estudos os pesquisadores realizaram vários testes com 4 e/ou 5 algoritmos diferentes. No trabalho publicado por Khan [Khan and Thakur 2022] por exemplo, 27 algoritmos foram testados.

Desta forma, o algoritmo de AM que apresentou maior número de registros foi o *Support Vector Machine* (SVM) com 39 (9,4%). Destaca-se que, o SVM predomina tanto nacional como internacionalmente, com respectivamente 7 (28%) e 32 (8,2%), em seguida tem-se *Naive Bayes* (NB) com 5 (30%) registros nacionalmente e 29 (7,4%) internacionalmente.

Algo que chama atenção é a adesão das redes neurais como, o *Long Short-Term Memory* (LSTM) e *Convolutional Neural Network* (CNN) internacionalmente, que vem ganhando espaço na área, no qual o número de estudos são respectivamente 28 (7,2%) e 25 (6,4%). Todavia, nacionalmente esse registro é menor, onde o CNN apresenta 1 (4%) registro como pode ser observado na Figura 6.

Figura 6. Algoritmos aplicados nos trabalhos.



3.8. Quais estudos apresentam resultados mais qualificados quanto às métricas de avaliação?

A presente QP8, foi criada tendo em vista identificar os resultados mais promissores alcançados pelas pesquisas. Vale ressaltar que, como mencionado, muitos artigos testam diversos algoritmos como também diversos *datasets*. Desta forma, a análise da Figura 7 apresenta nas linhas os *datasets* e os respectivos algoritmos testados, e na coluna são dispostos os trabalhos selecionados, sendo assim é feita a relação com o resultados alcançados. Entretanto, por conta do tamanho, para este artigo a análise está filtrada por cenário, constando assim apenas os artigos nacionais.

Sendo assim é notório que, o melhor resultado para o *dataset* Fake.br Corpus foi a do trabalho de ID A45 (referente ao artigo de [Sousa et al. 2022]), com a rede neural CNN, com 97,3% de acurácia. Destaca-se que com a criação do próprio corpus o melhor resultado foi do artigo de ID A38 (referente ao artigo de [Zhang et al. 2022]), com 96,39% de acurácia, com a combinação dos algoritmos *GRU + CBOW + CNN*. É notório que o CNN apresenta melhores resultados nos dois *datasets* disponíveis para a Língua Portuguesa.

Figura 7. Resultado dos algoritmos aplicado nos trabalhos selecionados.

		A2	A11	A29	A37	A38	A45
Fake.Br Corpus	AdaBoost		93,00%				
	CNN						97,30%
	NB	86,00%					
	SVM			80,00%	96,39%		
Corpus próprio	GRU + CBOW + CNN					96,39%	
	SGDClassifi..				92,90%		
	SVM			80,00%			

4. Considerações Finais

O presente artigo apresentou os trabalhos mais relevantes no contexto de detecção de *fake news* e suas respectivas soluções. Foi possível concluir que, nos últimos três anos, o número de artigos científicos tem passado por um crescimento no número de publicações, especialmente em 2022. As publicações científicas mais recorrentes no cenário internacional são em jornais, já no cenário nacional são em conferências. A RS identificou a Índia como o país com o maior número de publicações e o Inglês como o idioma mais adotado nos trabalhos. Em relação aos tipos de conteúdo, o *texto* é considerado o principal, porém novas combinações vêm sendo apresentadas como solução, tais como análise de *texto + contexto* e *texto + sentimento*. Mostrou-se também que mais de 55% dos estudos centralizaram a atenção para notícias publicadas em páginas jornalísticas. Em seguida, tem-se o *Twitter*, a rede social mais adotada para estudos na área de detecção de *fake news*. Em paralelo, os pesquisadores têm buscado adotar bases de dados próprias, porém, ainda há um número considerável de estudos que fazem uso de bases consolidadas, sendo o *Kaggle* e o *PolitiFact* as mais aderidas internacionalmente e a *Fake.br Corpus* nacionalmente. O

algoritmo de ML que apresentou maior número de registros foi o SVM com 39 (9,4%). Internacionalmente, chamou atenção a adesão das redes neurais como o LSTM e o CNN. Nacionalmente, essa adesão é menor.

Referências

- Allcott, H. and Gentzkow, M. (2017). Social media and fake news in the 2016 election. *Journal of Economic Perspectives*.
- Cerrao, N. G., CASTRO, F. F. d., and JESUS, A. F. d. (2018). O método de revisão sistemática da literatura (rs) na área da ciência da informação no brasil: análise de dados de pesquisa. *Informação & Tecnologia*.
- DataReportal (2023). DIGITAL 2023: GLOBAL OVERVIEW REPORT. Disponível em: <https://datareportal.com/reports/digital-2023-global-overview-report>. Acesso em: 02 Maio 2023.
- de Almeida, L. D., Fuzaro, V., Nieto, F. V., and Santana, A. L. (2021). Identificação de “fake news” no contexto político brasileiro: uma abordagem computacional. *Anais do II Workshop sobre as Implicações da Computação na Sociedade*.
- Keele, S. et al. (2007). Guidelines for performing systematic literature reviews in software engineering. Technical report, Technical report, Ver. 2.3 EBSE Technical Report. EBSE.
- Khan, Y. and Thakur, S. (2022). Fake news detection of south african covid-19 related tweets using machine learning. *International Conference on Artificial Intelligence, Big Data, Computing and Data Communication Systems (icABCD)*.
- Kumar, S., Kumar, S., Yadav, P., and Bagri, M. (2021). A survey on analysis of fake news detection techniques. *International Conference on Artificial Intelligence and Smart Systems (ICAIS)*.
- Martín, A., Huertas-Tato, J., Álvaro Huertas-García, Villar-Rodríguez, G., and Camacho, D. (2022). Facter-check: Semi-automated fact-checking through semantic similarity and natural language inference. *Knowledge-Based Systems*, 251.
- Medeiros, F. D. and Braga, R. B. (2020). Fake news detection in social media: A systematic review.
- Oshikawa, R., Qian, J., and Wang, W. Y. (2020). A survey on natural language processing for fake news detection.
- Reuters, I. and of Oxford, U. (2021). Reuters Institute Digital News Report 2021. Acesso em: 18 Maio 2022.
- Sharma, K., Qian, F., Jiang, H., Ruchansky, N., Zhang, M., and Liu, Y. (2019). Combating fake news: A survey on identification and mitigation techniques. *ACM Trans. Intell. Syst. Technol.*
- Sousa, F., Barbosa, A., Oliveira, C., and Braga, R. (2022). Detecção de fake news em língua portuguesa combinando redes neurais convolucionais e algoritmos de aprendizagem de máquina. *Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos*.
- Zhang, L., Huang, G., and Khan, M. (2022). A hybrid approach for network rumor detection based on attention mechanism and bidirectional gru model in big data environment. *Mob. Inf. Syst.*, 2022.